

REALCE DE TEXTURAS EM IMAGENS DE RADAR DE ABERTURA SINTÉTICA (SAR)
POR FILTROS DE REDUÇÃO DE 'SPECKLE'

Luciano Vieira Dutra
Nelson Delfino d'Ávila Mascarenhas

Instituto de Pesquisas Espaciais-INPE
Departamento de Processamento de Imagens-DPI
Caixa Postal 515
12201 - São José dos Campos - SP

RESUMO

Imagens de radar de abertura sintética têm sido cada vez mais utilizadas em sensoriamento remoto devido à sua característica de aquisição independente do clima (relacionamento com a umidade do solo). Todavia, um ruído abrangente denominado 'speckle', contamina esse tipo de imagem, dificultando a percepção da textura do terreno.

Vários filtros para redução de 'speckle' têm sido propostos na literatura, mas a avaliação do resultado, em geral, tem sido feita apenas de modo subjetivo. Neste trabalho é proposto um método para avaliar objetivamente os resultados dos filtros determinando os modelos estatísticos das texturas existentes e medindo uma distância entre esses modelos.

Os experimentos foram realizados usando uma imagem SAR580 com três classes e três filtros foram usados para supressão de 'speckle'. Foi observado melhor resultado com o uso do filtro sigma, o que coincidiu com o julgamento visual.

ABSTRACT

Synthetic aperture radar images are becoming an increasing important remote sensing data source because of their acquisition characteristics, such as, weather independence and soil humidity relationship. Unfortunately, they are disturbed by the so called 'speckle' noise which gives them a granular aspect masking the natural texture of terrain.

Several filter have been proposed in the literature in order to reduce the speckle noise, but, in general, evaluation of the results have been subjective. In this paper a method is proposed to evaluate objectively filtering results, by determining the statistical models of texture classes and measuring a similarity distance between the classes. The experiments were made using a SAR580 image with three classes and three filters were used for speckle suppression. The results showed a better performance with the sigma filter which agrees with the visual judgment.

1- INTRODUÇÃO

Imagens de radar de abertura sintética (SAR) significam um avanço nos métodos de aquisição de informação em Sensoriamento Remoto, pois este sensor independe de condições climáticas para aquisição dos dados (característica muito importante principalmente para a região amazônica, que tem muitas áreas permanentemente cobertas por nuvens).

Além disso, a imagem que se observa guarda relação com um importante parâmetro de análise dos solos: sua umidade. Outra característica relevante que auxilia a avaliação e levantamento de recursos terrestres, que é a textura do terreno, não se reflete adequadamente em imagens SAR pois essas estão contaminadas por um ruído abrangente de caráter multiplicativo, denominado ruído 'speckle', que mascara essa textura. Filtros são propostos na literatura para redução desse tipo de ruído, mas a utilização desses acaba, muitas vezes, reduzindo também a percepção dessa textura por suavização excessiva. Uma das maneiras de caracterizar texturas estatísticas que é o caso da maioria das texturas naturais, é a utilização de modelos matemáticos, caso dos modelos autorregressivos e média móvel (ARMA). A obtenção desses modelos para cada classe textural do terreno visa então caracterizá-las do ponto de vista estatístico e fornece um meio para distinção objetiva entre elas.

Neste trabalho pretende-se avaliar, dentre os principais filtros de redução de 'speckle', qual deles é mais eficiente em termos de redução de 'speckle', mantendo-se o máximo possível a textura original.

Essa eficiência é medida em termos de uma distância entre modelos. Quanto maior a distância entre os modelos, melhor a separabilidade das texturas. Consegue-se desta forma um critério objetivo para avaliar o resultado desses filtros, o que até agora tem sido feito apenas de modo subjetivo. Foram testados os seguintes filtros: sigma, de Lee e mediana sobre uma imagem da missão SAR-580 sobre a Alemanha e os resultados tabulados foram comparados também com a situação de nenhum filtro aplicado (imagem original).

O trabalho está organizado da seguinte maneira: na seção 2 é apresentada a teoria de modelos de Séries Temporais unidimensionais, e a seção 3 apresenta o método de se obter

modelos bidimensionais a partir de modelos unidimensionais. A seção 4 traz a definição da distância entre modelos usada nesse trabalho e finalmente a seção 5 apresenta as experiências realizadas e conclusões.

2- O MODELO ARMA DE SÉRIES TEMPORAIS

Uma série temporal é caracterizada por uma sequência de valores no tempo y_1, y_2, \dots, y_n . O valor médio de y_i é μ . Essa série é modelada como sendo gerada a partir de uma sequência de 'shocks' independentes, que são realizações de um processo de ruído branco com média zero e variância σ_w^2 , que passam por um filtro linear que caracteriza o processo (Figura 1) (Box e Jenkins, 1970).



Fig. 1 - Representação do filtro gerador do processo

Esse filtro é definido pela equação diferença (Equação 1) denominado modelo ARMA(p,q).

$$y_i = \sum_{k=0}^q \alpha_k w_{i-k} + \sum_{j=1}^p \beta_j y_{i-j} + \mu \quad (\alpha_0=1) \quad (1)$$

O modelo (1) é unidimensional e poderia ser usado para descrever uma imagem se essa fosse linearizada concatenando-se linhas ou colunas. Coeficientes não nulos em atrasos múltiplos do tamanho da linha corresponderiam a pontos colocados espacialmente vizinhos ao ponto sendo gerado.

Da Equação (1) pode-se ressaltar dois casos particulares: o primeiro é o denominado modelo autorregressivo de ordem p (AR(p)) quando $q=0$ (Equação 2):

$$y_i = \beta_1 y_{i-1} + \beta_2 y_{i-2} + \dots + \beta_p y_{i-p} + w_i + \mu \quad (2)$$

O segundo caso particular é denominado modelo média-móvel de ordem q (MA(q)) que deriva (1) fazendo $p=0$ (Equação 3):

$$y_i = \alpha_0 w_i + \alpha_1 w_{i-1} + \dots + \alpha_q w_{i-q} + \mu \quad (3)$$

onde $\alpha_0 = 1$.

Para se obter modelos ARMA(p,q) que caracterizem um processo estocástico, normalmente se supõe que esse processo seja estacionário no sentido amplo, ou seja, ele não varia muito além da média ou não foje da média sistematicamente. Isto supõe que as

estatísticas de 1a. e 2a. ordem do processo são dependentes do intervalo entre tempos (também chamado de atraso) e não da posição temporal. (Box e Jenkins, 1970).

A ordem e uma estimativa dos parâmetros do modelo são obtidos com a ajuda da função de autocorrelação (FAC) e autocorrelação parcial (FAP) definidas a seguir.

Supondo $\mu = 0$, a autocovariância para um processo estocástico estacionário é dada por

$$\gamma_k = E(y_i y_{i-k}) \quad (4)$$

É fácil verificar de (2) e (4) que para um processo AR(p) vale a relação:

$$\gamma_k = \beta_1 \gamma_{k-1} + \beta_2 \gamma_{k-2} + \dots + \beta_p \gamma_{k-p} \quad (5)$$

A função de autocorrelação (FAC) é dada por:

$$\rho_k = \gamma_k / \gamma_0 \quad (6)$$

Daí resultando que:

$$\rho_k = \beta_1 \rho_{k-1} + \beta_2 \rho_{k-2} + \dots + \beta_k \rho_{k-p} \quad (7)$$

Fazendo-se $k = 1, 2, \dots, p$ obtêm-se as chamadas equações Yule-Walker, que são também soluções para o problema de predição linear (Marple, 1987).

Seja ϕ_{ki} o i -ésimo coeficiente num processo auto-regressivo de ordem k . Dentre os coeficientes ϕ_{ki} a função ϕ_{kk} (encarada como função de k) tem especial interesse e é chamada função de autocorrelação parcial (FAP(k)). A FAP se anula para $k > p$ quando o processo é AR(p). Por outro lado, pode-se mostrar que, para um processo MA(q), a função de autocorrelação (FAC) se anula para atrasos maiores do que q .

Para o modelo ARMA completo, nem a FAC ou a FAP se anulam. De acordo com essas propriedades é possível tentar identificar o modelo subjacente a um processo calculando a FAC e a FAP e observando seus aspectos.

Como na prática, porém, a quantidade de dados de treinamento é limitada, e considerando-se a variância dos estimadores da FAC e da FAP, não é possível determinar com certeza absoluta qual o modelo de um processo. Para resolver esse problema e tornar o processo de identificação bem determinado, a literatura apresenta certos índices como o índice de Akaike (1969) que indica o melhor modelo quando minimizado. De qualquer forma é sempre

possível determinar um modelo AR(p) para caracterizar um processo. Nesse trabalho se determinarão apenas modelos AR(p).

Uma vez obtida uma indicação do tipo e da ordem do modelo, a estimativa dos parâmetros α_i e β_j é feita em dois passos: 1) uma estimativa preliminar que utiliza a função de autocorrelação e que serve como ponto de partida para 2) uma estimativa de máxima verossimilhança que usa os dados diretamente.

A estimativa preliminar para o processo AR(p) é feita substituindo-se as correlações teóricas nelas estimadas na equação de Yule Walker. Tendo sido identificado um modelo tentativo com certos parâmetros iniciais, deseja-se escolher uma melhor estimativa para esses coeficientes. O método mais usado é o método dos mínimos quadrados que corresponde à estimativa de máxima verossimilhança sob a hipótese gaussiana para o ruído. Como se trata de um problema de estimação não-linear, métodos iterativos como de Gauss-Newton são utilizados (Granger e Newbold, 1977).

Deseja-se também calcular uma estimativa do erro de cálculo dos parâmetros. Sabe-se que as estimativas de máxima verossimilhança atingem assintoticamente o limite de Cramer-Rao e têm distribuição multivariada gaussiana. A raiz quadrada dos elementos da diagonal principal da matriz de covariância dado pelo limite Cramer-Rao dá o desvio padrão ($SE(\theta_j)$) de cada parâmetro. Assim, para que um parâmetro seja significativamente diferente de 0 com 95% de probabilidade basta verificar se $|\theta_j| > 2 SE(\theta_j)$.

O conhecimento do erro padrão para os parâmetros auxilia o processo de identificação, pois os parâmetros não significativos podem ser retirados do modelo e reestimados os parâmetros restantes (Dutra, 1988).

3- RELAÇÃO ENTRE MODELOS UNIDIMENSIONAIS CONCATENADOS E MODELOS BIDIMENSIONAIS

Dutra e Mascarenhas (1989) desenvolveram um método aproximado para determinar modelos ARMA 2D a partir de concatenação de linhas ou colunas da imagem. Com o processo de concatenação de segmentos de linhas ou colunas transforma-se a imagem, que é um processo estocástico de duas dimensões (também chamado de campo aleatório), em um processo unidimensional, onde se

pode aplicar o método descrito na seção 2 com certas adaptações.

A metodologia para determinar modelos AR, pode ser sintetizada nos seguintes passos:

a) Adquirir os dados referentes às áreas de treinamento, concatenando-se segmentos de linha ou coluna.

b) Retirar a média do sinal e plotar a função FAP. Pela observação dessas funções determinar p tal que a função seja considerada nula.

c) Obter a estimativa preliminar para o modelo AR(p)

d) De posse do erro padrão para os coeficientes preliminares zerar os não significativos que não mais serão considerados para otimização.

e) Submeter o modelo à estimativa de máxima verossimilhança. Observar que a natureza originalmente bidimensional dos dados vai revelar rapidamente a região de suporte do filtro.

4- DISTÂNCIA ENTRE MODELOS

Distâncias são funções que podem ser usadas em processamento de sinais e imagens (Basseville, 1989) para resolver vários problemas tais como segmentação, classificação, descrição, etc. Distâncias podem ser definidas entre modelos, funções, distribuições de probabilidades, pontos ou conjuntos e servem para medir a similaridade entre dois objetos. Por força da própria definição, se a distância entre dois objetos for zero os objetos são iguais. Algumas vezes se define distância entre objetos de classes diferentes; nesse caso um processo de detecção é implícito. Itakura (1975) introduziu uma distância entre um sinal (representado pelo seu modelo e matriz de autocovariância) e um modelo. O sinal é associado ao modelo que for mais próximo.

No caso do presente trabalho essa distância não se aplica pois não existe um sinal que se quer classificar; deseja-se apenas medir a separabilidade dos modelos.

Modelos autorregressivos podem ser colocados em forma vetorial. Assim, torna-se natural o uso do ângulo entre os vetores como medida de distância ou similaridade.

A Equação 2 pode ser colocada na seguinte forma

$$\tilde{y}_i(j) = \underline{\beta}_j \tilde{y}_i(j) + w_i \quad (8)$$

onde $\underline{\beta}_j$ é o vetor dos coeficientes do modelo da classe ω_j conveniente ordenado, $\tilde{y}_i(j)$ é o sinal centralizado no tempo i ou seja $\tilde{y}_i(j) = y_i(j) - m_j$, m_j é a média do processo $y_i(j)$ e $\mu = (1 - \sum \beta_j)^m$ na Equação 2, e $\tilde{y}_i(j)$ é um vetor de saídas centralizadas passadas ao tempo i também convenientemente ordenada. O ângulo θ_{jk} entre os modelos $\underline{\beta}_j$ e $\underline{\beta}_k$ é dado por

$$d(\underline{\beta}_j, \underline{\beta}_k) = \theta_{jk} = \arccos \frac{\underline{\beta}_j \underline{\beta}_k}{|\underline{\beta}_j| |\underline{\beta}_k|} \quad (9)$$

Observa-se que θ_{jk} atende às propriedades de distância tais como é sempre não negativa e satisfaz a desigualdade do triângulo e a propriedade da simetria. A outra propriedade de que se $d(\underline{\beta}_j, \underline{\beta}_k) = 0 \Rightarrow \underline{\beta}_j = \underline{\beta}_k$ em geral não é satisfeita pela Equação (9) mas considerando que é filtro AR, pela condição de estabilidade e identificabilidade de modelos unidimensionais (Box e Jenkins, 1970), existe apenas um filtro em cada direção no espaço de coeficientes, assim pode-se afirmar que se $d(\underline{\beta}_j, \underline{\beta}_k) = 0 \Rightarrow \underline{\beta}_j = \underline{\beta}_k$.

A extensão desse critério para modelos bidimensionais é simples, pois basta considerar uma região de suporte suficientemente grande para conter todos os modelos em avaliação, ordenar os coeficientes sistematicamente no vetor e considerar os coeficientes não existentes como zero.

5- EXPERIÊNCIAS REALIZADAS E CONCLUSÕES

Testes foram efetuados em uma imagem de radar de abertura sintética da missão SAR580 sobre uma área da Alemanha.

Essa imagem foi filtrada pelos algoritmos de suavização de 'speckle' denominados filtros de Lee e Sigma com parâmetro desvio padrão $\sigma = 0.55$ conforme revisados no trabalho de Li e Banon (1988). Obteve-se também uma imagem filtrada por filtro mediana não recursivo em região 3×3 conforme desenvolvido no trabalho de Castellari e Dutra (1988). No conjunto de três imagens filtradas mais a imagem original foram identificadas três classes: Floresta, Cultura Anual e Restos de Cultura. De cada classe e em áreas correspondentes em cada imagem foi adquirido um conjunto de 1000 pontos para treinamento obtidos por concatenação de 100 segmentos de linha de cada classe; cada segmento com 10 pontos em sequência.

Para identificação e estimação dos parâmetros dos modelos AR de cada classe e para cada imagem filtrada mais a imagem original, foi utilizado o programa PEST que acompanha o livro de Brockwell e Davis (1987).

A Figura 2 apresenta os modelos autorregressivos obtidos com o canal original para as classes Floresta, Cultura anual e Restos de cultura. A Figura 3 apresenta os modelos para o canal filtrado pelo filtro de Lee; A Figura 4 pelo filtro Sigma com $\sigma = 0.55$ e a Figura 5 com o filtro mediana.

(O = referência do filtro)

		○	.250	.
.055	.604		-.111	.050
.00	-.222		.00	.

(a)

	○	.469	-.180	.063
.051	.622		-.337	.102
	-.252	.098		

(b)

	○	.500	-.145
.05	-.683	-.320	
	-.290	.121	

(c)

Fig. 2 - Modelos autorregressivos (AR) para o canal original e classes (a) Floresta, (b) Cultura Anual e (c) Restos de Cultura.

	○	.748	.
.	1.116	-.824	.
.	-.264	.196	.

(a)

	○	.875	-.160
.	1.055	-.889	.133
.	-.272	.210	.

(b)

	○	.846	-.149
.110	1.118	-.946	.107
-.093	-.3206	.282	.

(c)

Fig. 3 - Modelos autorregressivos (AR) para o canal filtrado pelo filtro de Lee e mesmas classes da Figura 2.

	○	.2943	.
.273	.538		.
-.099	-.190		.

(a)

	○	.4579	-.096
.281	.507	-.1105	.
-.1811	-.1353	.	.

(b)

	○	.553	-.1532
.259	.4684	-.086	.
-.1467	-.114	.	.

(c)

Fig. 4 - Modelos AR para o canal filtrado pelo filtro Sigma com $\sigma = 0.55$ e mesmas classes da Figura 2.

	○	.443	.
.2277	.6546	-.1336	.
-.212	.	.	.

(a)

	○	.5133	.
.218	.636	-.255	.
-.148	-.114	.	.

(b)

	○	.585	-.128
.222	.596	-.212	.
-.136	-.136	.	.

(c)

Fig. 5 - Modelos AR para o canal filtrado por mediana e mesmas classes da Figura 2.

A Tabela 1 apresenta os ângulos obtidos pela Equação (9) quando aplicados aos modelos das Figuras 2 a 5.

TABELA 1

DISTÂNCIAS (ÂNGULO) ENTRE MODELOS AUTORREGRESSIVOS OBTIDOS PARA AS DIVERSAS CLASSES E PARA OS CANAIS ORIGINAL E FILTRADOS. ÂNGULOS EM RADIANOS..

FILTROS	DISTÂNCIAS		
	$d(\beta_a, \beta_b)$	$d(\beta_b, \beta_c)$	$d(\beta_a, \beta_c)$
Original	0.286	0.149	0.353
Lee	0.151	0.102	0.153
Sigma	0.308	0.158	0.421
Mediana	0.214	0.175	0.292

Como se pode observar na Tabela 1 o melhor resultado se deu com o uso do filtro Sigma com parâmetro $\sigma = 0.55$, situação em que todas as distâncias (ângulos entre modelos) aumentaram. Para o filtro de Lee todas as distâncias diminuíram e com o filtro da mediana o resultado foi intermediário pois apenas uma das distâncias aumentou. As Figuras de 6 a 9 apresentam as imagens originais e filtradas pelos diversos filtros utilizados. Na Figura 7, a imagem parcialmente filtrada pelo filtro de Lee (lado esquerdo da foto) mostra que a suavização foi excessiva, explicando a diminuição da separabilidade das texturas. O fato de que os ângulos são maiores com a imagem filtrada pelo filtro Sigma, comparado com o caso da imagem original, significa que as texturas são mais separáveis na imagem filtrada por esse filtro. Esses resultados coincidem com a opinião de Ii e Banon (1988) ao observar o resultado visual das imagens filtradas.

Pode-se concluir então que o método apresentado desenvolve um critério objetivo que tem boa concordância com os julgamentos visuais com respeito a esse importante aspecto da imagem que é a textura.

Para o futuro pretende-se avaliar o processo em imagens controladas ou seja utilizando-se de texturas bem definidos sobre as quais será simulado o ruído 'speckle' e incluir nessa nova avaliação outros filtros propostas na literatura que não foram testados no presente experimento.

6- AGRDECIMENTOS

Os autores agradecem a Silvia Ii e ao Dr. Gerald Banon pela cessão de fotos de radar filtradas.

7- REFERÊNCIAS BIBLIOGRÁFICAS

- AKAIKE, H.; Fitting autorregressive models for prediction. Ann. Inst. Static. Math. 21:243-247, 1969.
- BASSEVILLE, M.; Distance Measures for Signal Processing and Pattern Recognition, Signal Processing 18(4):349-369, Dec 1989.
- BOX, G.E.P.; JENKINS, G.M.; Time Series Analysis Forecasting and Control. Holden Day, San Francisco, 1970.
- BROCKWELL, P.J.; DAVIS, R.A.; Time Series Theory and Methods, Berlin, Springer-Verlag, 1987.

CASTELLARI, S.P.; DUTRA, L.V.; Implementação de um Filtro de Ordem e suas Aplicações em Imagens de Radar (SAR) In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, V, Natal, RN, 11-15 outubro 1988. Anais. São José dos Campos, INPE, pag. 537-544.

DUTRA, L.V.; Identificação Estatística Preliminar de Imagens de Radar: Modelos Autorregressivos e Média Móvel (ARMA). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, V, Natal, RN, 11-15 outubro 1988. Anais. São José dos Campos, INPE, v.2, pag. 517-524.

DUTRA, L.V.; MASCARENHAS, N.D.A.; Análise de Texturas em Imagens de Radar Usando Modelos ARMA. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS, II, Águas de Lindóia, SP, 1989. Anais. São José dos Campos, INPE, 1989, pag. 77-88.

GRANGER, C.W.J.; NEWBOLD, P.; Forecasting Economic Time Series, New York, NY, Academic Press, 1977.

ITAKURA, F.; Minimum Prediction Residual Principle Applied to Speech Recognition, IEEE Transaction on Acoustics Speech and Signal Processing, 23(1):67-72, Feb 1975.

MARPLE, S.L.; Digital Spectral Analysis. Englewood Cliffs, N.J., Prentice-Hall, 1987.

II, S.S.; BANON, G.J.F.; Comparação de Desempenho Entre Vários Filtros para Redução em Imagens de Radar. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, V, Natal, RN, 11-15 outubro 1988. Anais. São José dos Campos, INPE, v.3, pag. 567-571.

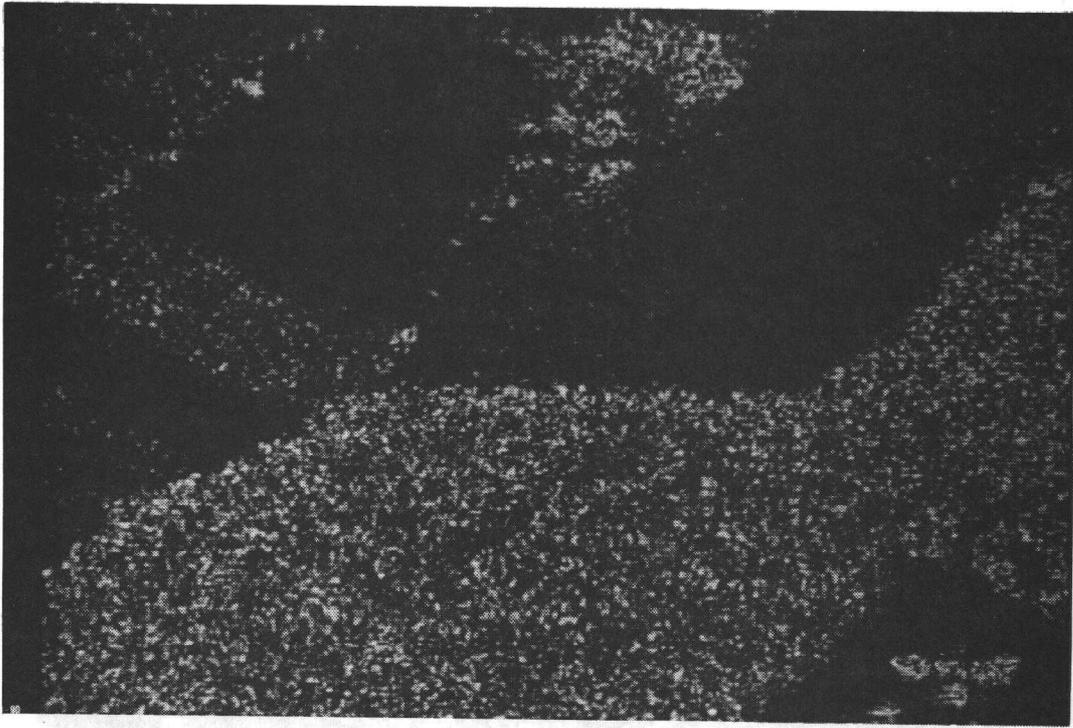


Fig. 6 - Imagem SAR580 original

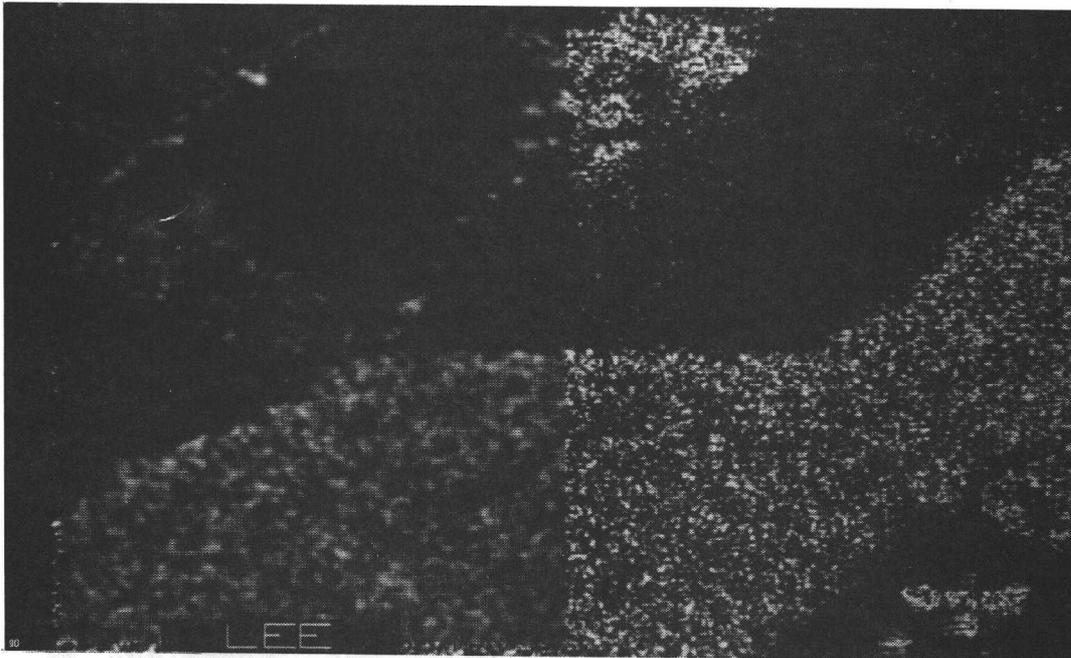


Fig. 7 - Imagem filtrada pelo filtro de Lee
(lado esquerdo da foto)

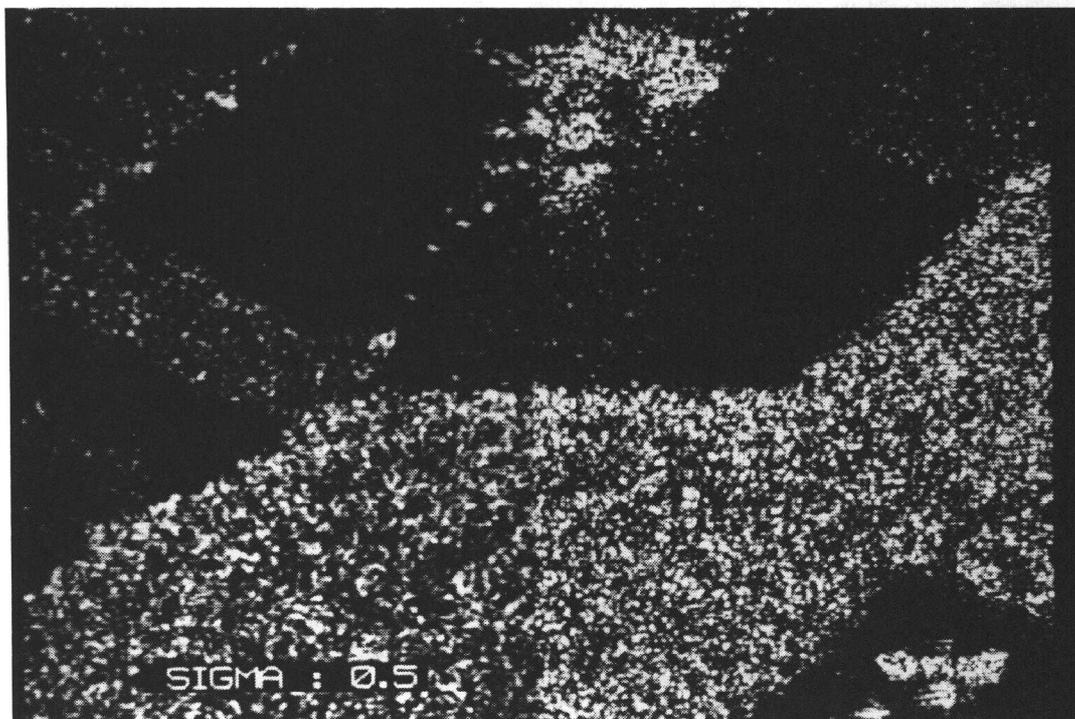


Fig. 8 - Imagem filtrada pelo filtro Sigma com $\sigma = 0.55$
(lado esquerdo da foto)

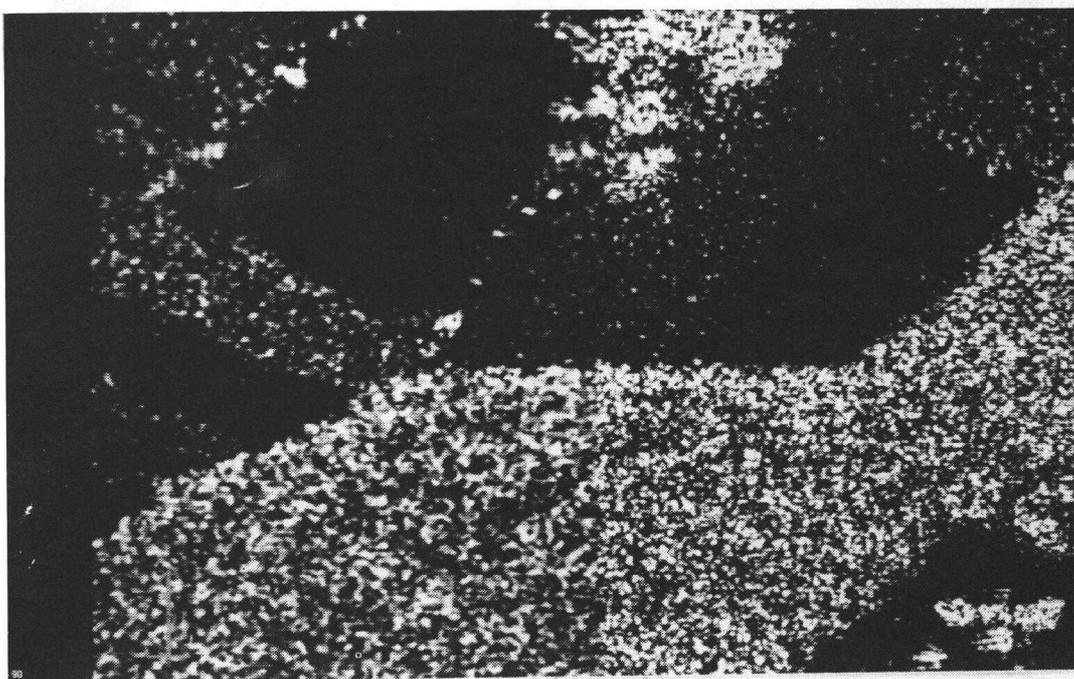


Fig. 9 - Imagem filtrada por mediana não recursiva em região 3x3.